Google Cloud のデータ パイプライン サービスの紹介と選び方

Google Cloud Japan
Data Analytics Specialist
西村哲徳

アジェンダ

- Google Cloud の Smart Analytics Solutions
- データ パイプライン サービスを選択する
- Google Cloud のデータパイプライン サービス

Google Cloud の Smart Analytics Solutions

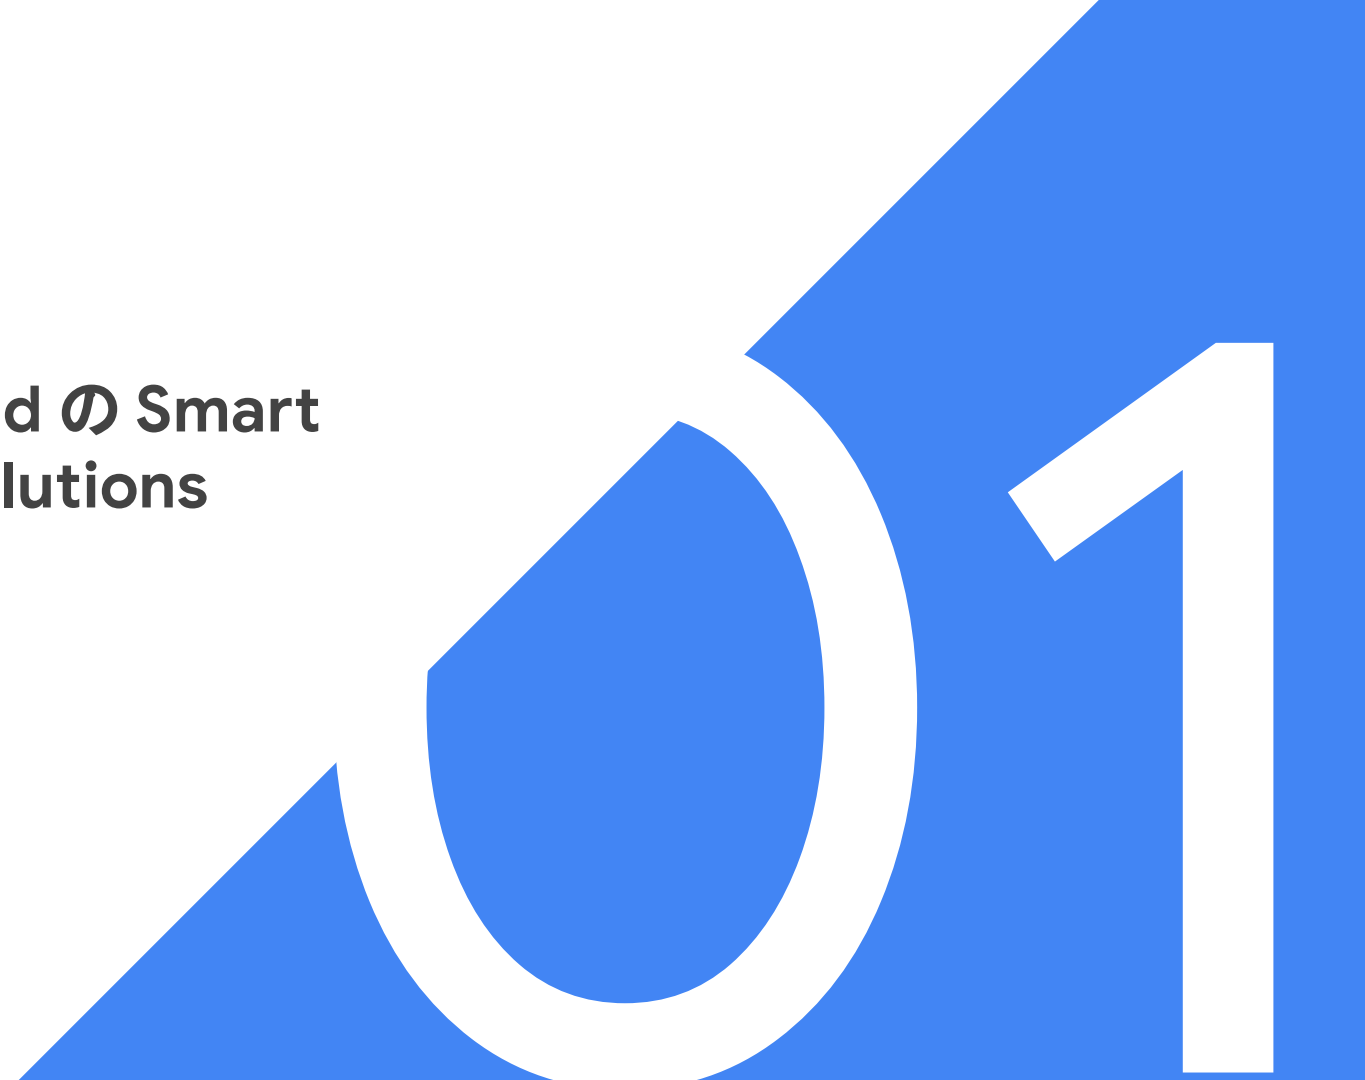

Smart Analytics によるサイロ化したデータの統合

リアルタイムに、シームレスに、未来を予測。

エンドツーエンドのデータ分析プラットフォーム

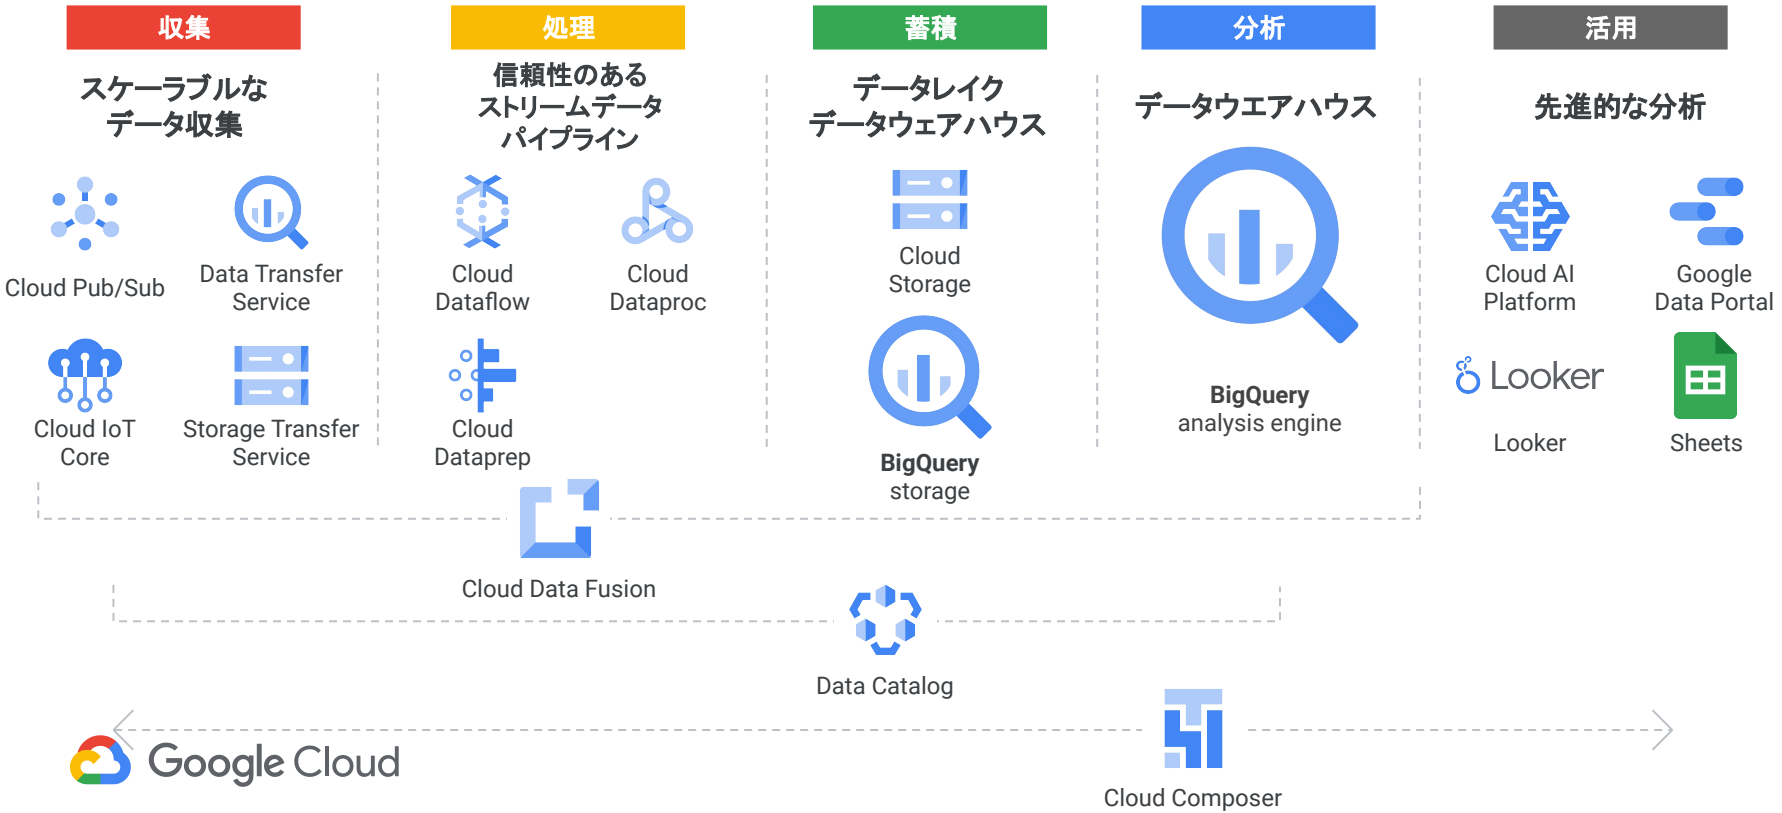

データ パイプライン サービスを選択する

02

データ パイプラインとは？

- データソースからデータを収集して、クレンジング、エンリッチメント、各種チェック等の変換処理をして分析可能な形にして格納する一連のデータ処理のこと
- データ パイプラインを構成する要素
  - データソース / シンク
    - ソース : 業務アプリやウェブ、モバイル等のデータ
    - シンク : 分析用に処理されたデータ、中間データ
    - 主に RDBMS、NoSQL、メッセージング、ストレージ サービス、SaaS 等
  - データ処理
    - データの変換処理を実行（ジョブ、タスク）
  - ワークフロー
    - 依存関係のあるデータ処理の実行順序を制御、管理
    - スケジュール
- 製品の観点では、データ処理製品にワークフローの機能が含まれていることが多い

データ処理の方式 ETL と ELT

E（抽出）、T（変換）、L（ロード）

ETL : 抽出したデータを変換してからデータ ウェアハウスにロードすること

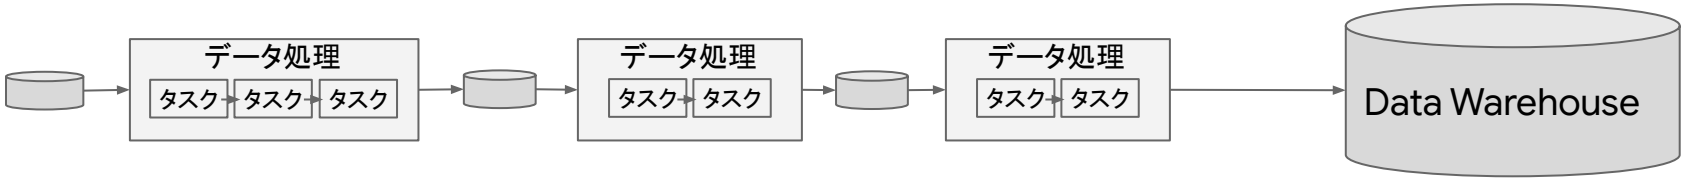

ELT : 抽出したデータをデータ ウェアハウスにロードしてその中で変換処理をすること

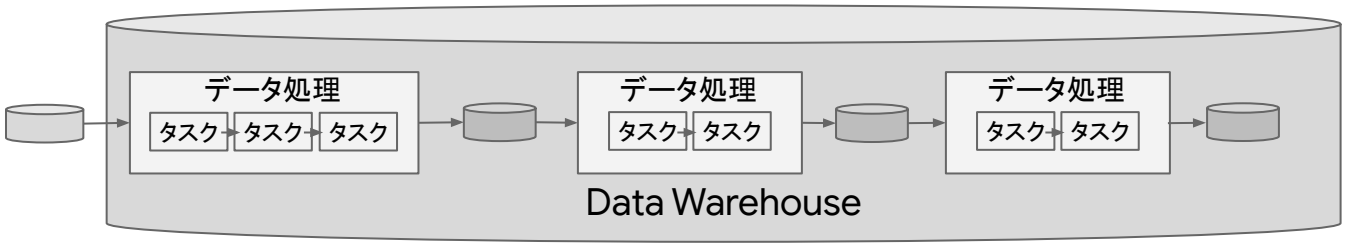

ワークフローの選び方

- 処理の実行順序の柔軟性（順次実行、分岐等）
- スケジュール機能
- 連携可能なサービスの種類
- エラー処理
  - リトライ
  - 通知
  - 途中からの実行
  - 冪等
- 開発方法
- ワークフローの監視
- 環境の管理

Google Cloud のデータ パイプライン サービス

データ パイプライン サービス

- Google Cloud のサービスをデータ処理、ワークフローの観点で分けると

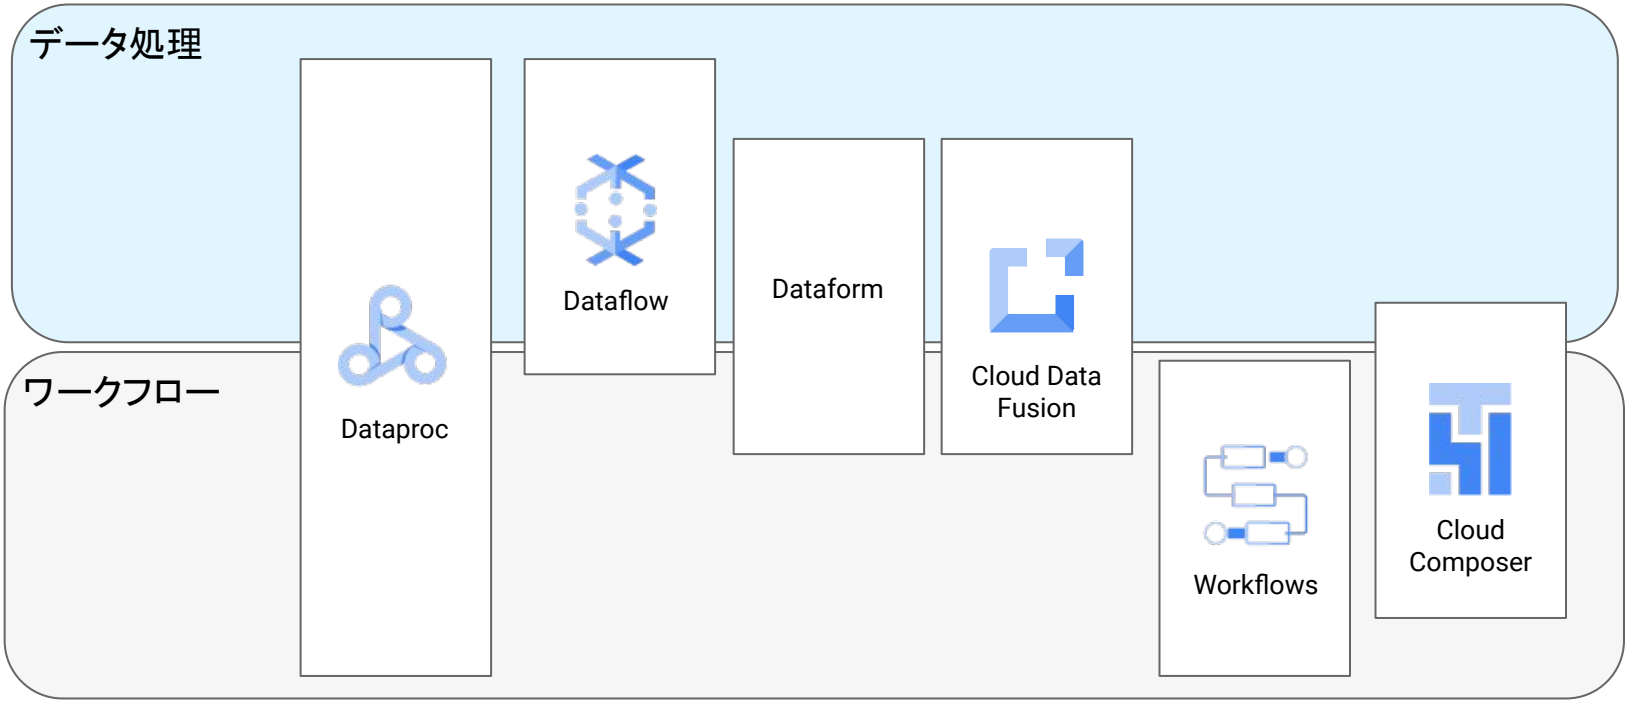

ご紹介する
Google Cloud のワークフロー機能を含むサービス

- Cloud Composer
- Workflows
- Cloud Data Fusion
- Dataform（preview）

サービスの比較

	Cloud Composer	Workflows	Cloud Data Fusion	Dataform
ユースケース	**複数のデータ処理サービスを束ねるワークフロー エンジンとしての利用 複雑なワークフローやエラー ハンドリングなど**	**API ベースのサービスを束ねるワークフローエンジンとしての利用。複雑な処理の自動化**	**データ統合のための変換処理としての利用がメイン**	**DWH 内での依存関係をもった変換処理をバッチとして実行**
運用・管理	フルマネージド	サーバレス	フルマネージド	サーバレス
依存関係の定義	タスクの順次実行だけでなく分岐など柔軟な定義が可能	タスク（ステップ）の順次実行だけでなく分岐など柔軟な定義が可能	変換処理（パイプライン ノード）の流れの依存関係定義がメイン。	変換処理（アクション）の順次実行定義が可能
スケジュール機能	実行間隔だけでなく開始日、終了日などの定義でより柔軟なスケジューリングが可能	Cloud Scheduler（フルマネージドのcronサービス）で定義	cron ベースでの定義 （GUI で定義可能）	cron ベースでの定義 （GUI で定義可能）
開発言語	Python でワークフローの定義	YAML でワークフローの定義	GUI でパイプラインの定義 ビルトインの変換処理も多数提供されている	主に SQL で JavaScript やビルトイン関数などを合わせてパイプラインの定義
連携可能なサービス	様々な種類のサービスと連携できるようになっている。（Operatorとして提供） カスタム Operator を作成可能	googleapi と http	多数のサービスとの連携が可能。（プラグインとして提供）カスタムプラグインの作成も可能	特定の DWH 内での処理のみ
エラー処理	タスクのリトライの柔軟な設定が可能。 失敗したワークフローの再実行、途中のタスクからの実行など柔軟な再実行が可能	ステップのリトライの柔軟な設定が可能。失敗したワークフローの再実行というよりは新たに実行しなおす。	変換処理のリトライはビルトインの種類による。失敗したパイプラインは、再実行というよりは新たに実行しなおす。	リトライ処理はなし。失敗したパイプラインは再実行というよりは新たに実行しなおす。パイプラインの途中からの実行は可能
エラー通知	email 通知やエラー時の callback の定義で通知可能	単体ではエラー通知の機能はない	email 、http コールでの通知	email 、slack での通知
監視	様々な角度から監視できるように多数の UI を提供	実行状態の監視は明示的にログ出力が必要	実行状態をログで監視可能 変換の input output の件数も監視可能	UI のログから実行状態を監視可能

Cloud Composer

- Apache Airflow のマネージド サービス
- ワンクリックで Apache Airflow の実行環境の構築、および、ワークフローのデプロイが実施可能
- Python でワークフローを記述
- 各 Google Cloud サービス（BigQuery、Cloud Dataflow、Cloud Dataproc など）と連携するための パッケージが プリ インストール

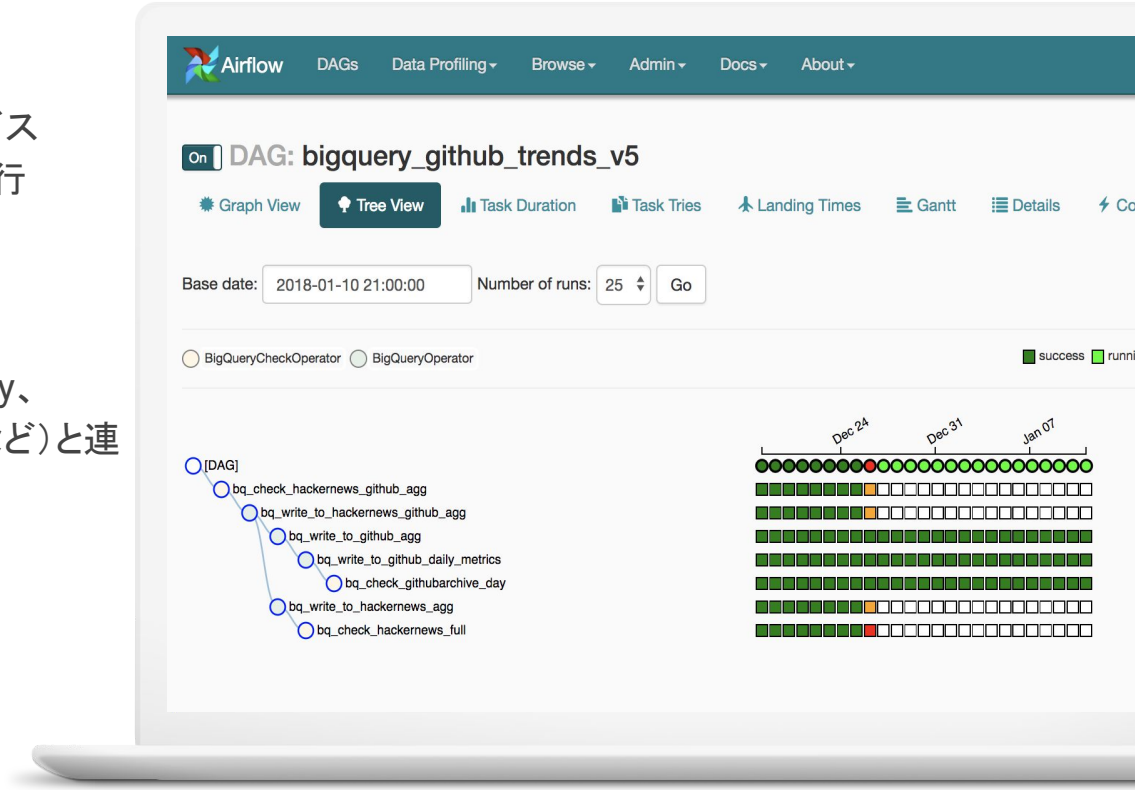

Cloud Composer の開発

- Python でワークフロー（DAG）を開発
- Operator で各タスクを定義
  - 多数のビルトイン operator
  - カスタムで開発も可能
- Airflow の dags フォルダに Python のコードを配置

```
default_dag_args = {
    # The start_date describes when a DAG is valid / can be run. Set this to a
    # fixed point in time rather than dynamically, since it is evaluated every
    # time a DAG is parsed. See:
    # https://airflow.apache.org/faq.html#what-s-the-deal-with-start-date
    'start_date': datetime.datetime(2018, 1, 1),
}

# Define a DAG (directed acyclic graph) of tasks.
# Any task you create within the context manager is automatically added to the
# DAG object.
with models.DAG(
        'composer_sample_simple_greeting',
        schedule_interval=datetime.timedelta(days=1),
        default_args=default_dag_args) as dag:
    # [END composer_simple_define_dag]
    # [START composer_simple_operators]
    def greeting():
        import logging
        logging.info('Hello World!')

    # An instance of an operator is called a task. In this case, the
    # hello_python task calls the "greeting" Python function.
    hello_python = python_operator.PythonOperator(
        task_id='hello',
        python_callable=greeting)

    # Likewise, the goodbye_bash task calls a Bash script.
    goodbye_bash = bash_operator.BashOperator(
        task_id='bye',
        bash_command='echo Goodbye.')
    # [END composer_simple_operators]

    # [START composer_simple_relationships]
    # Define the order in which the tasks complete by using the >> and <<
    # operators. In this example, hello_python executes before goodbye_bash.
    hello_python >> goodbye_bash
    # [END composer_simple_relationships]
  # [END composer_simple]
```

Cloud Composer の依存関係の定義

- Operator を >> でつなぐことで順次実行を定義
- ブランチ化や条件分岐などの複雑な処理も定義可能

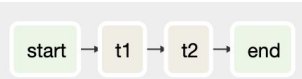


```
with models.DAG(...
) as dag:

    start = DummyOperator(task_id="start")
    end = DummyOperator(task_id="end")

    t1 = BashOperator(
        task_id="t1",
        bash_command="echo t1",
    )
    t2 = BashOperator(
         task_id="t2",
         bash_command="echo t2 "
     )

    start >> t1 >> t2 >> end
```

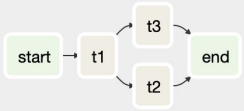


```
with models.DAG(...
) as dag:

    start = DummyOperator(task_id="start")
    end = DummyOperator(task_id="end")

    t1 = BashOperator(
        task_id="t1",
        bash_command="echo t1",
    )
    t2 = BashOperator(
         task_id="t2",
         bash_command="echo t2 "
     )
    t3 = BashOperator(
         task_id="t3",
         bash_command="echo t3 "
     )

    start >> t1 >> [t2,t3] >> end
```

Cloud Composer の連携可能なサービス operators

- 3 つのタイプの Operators
  - Action: 処理の実行、または外部システムに処理の実行を依頼（例: dataflowジョブの起動）
  - Transfer: データの移動
  - Sensors: 特定の基準が満たされるまで実行（例: ファイル検知）

Azure: Microsoft Azure

- Logging
- Azure Blob Storage
- Azure File Share
- Azure CosmosDB
- Azure Data Lake
- Azure Container Instances

AWS: Amazon Web Services

- Logging
- AWS EMR
- AWS S3
- AWS Batch Service
- AWS RedShift
- AWS DynamoDB
- AWS Lambda
- AWS Kinesis
- Amazon SageMaker

GCP: Google Cloud Platform

- Logging
- GoogleCloudBaseHook
- BigQuery
- Cloud Spanner
- Cloud SQL
- Cloud Bigtable
- Cloud Build
- Compute Engine
- Cloud Functions
- Cloud DataFlow
- Cloud DataProc
- Cloud Datastore
- Cloud ML Engine
- Cloud Storage
- Transfer Service
- Cloud Vision
- Cloud Text to Speech
- Cloud Speech to Text
- Cloud Speech Translate Operators

Cloud Composer のスケジュール機能

- cron ベースでの定義
  - プリセット: None、@once、@hourly、@daily、@weekly、@monthly、@yearly
  - cron 形式の定義
- 開始日、終了日、実行間隔を定義することで DAG の実行をアトミックで冪等に
  - 各 DAG 実行にいつ分の実行かを示す execution_date が割り当てられる。
  - 同一 execution_date は 1 つのみ
  - 再実行しても execution_date は変わらない
  - backfill 、catchup の実行も可能

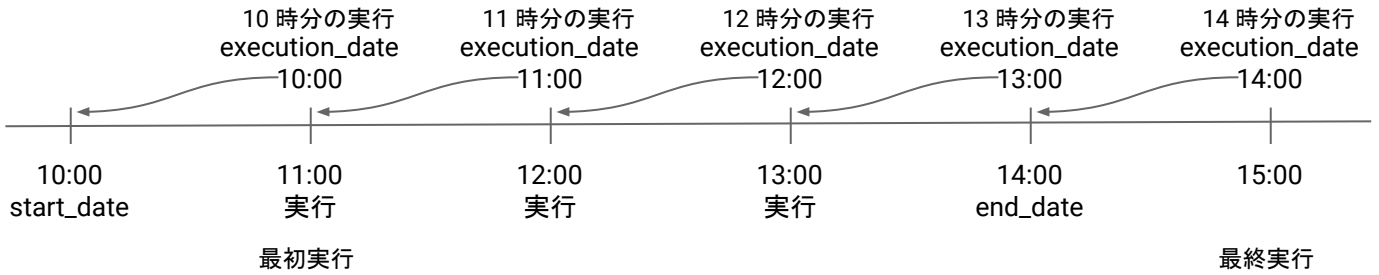

Cloud Composer のエラー処理

- 通知
  - 失敗時、リトライ時に email 送信可能（メールサービスは自前で要準備）
  - 失敗時、リトライ時、成功時に callback が指定できるので email 以外のカスタマイズした通知も可能

```
default_args = {
    "start_date": days_ago(1),
    "email": ["te****@google.com"],
    "email_on_failure": True,
    "email_on_retry": False
 }
```

```
def send_message(context):
    通知処理

default_args = {
    "start_date": days_ago(1),
    "on_failure_callback": send_message
}
```

Cloud Composer のエラー処理

- 実行中のタスクに対するリトライ設定可能
  - リトライ回数、間隔
- 失敗した DAG の再実行
  - DAG のステータスをクリアで、同一の execution_date で再実行
  - 途中のタスクからのレジューム実行も可能

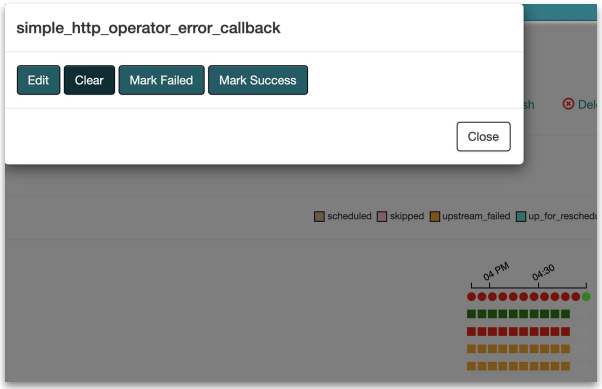

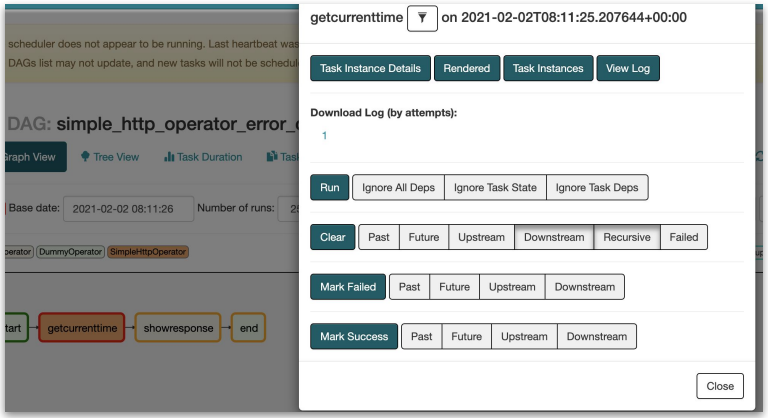

Cloud Composer の監視

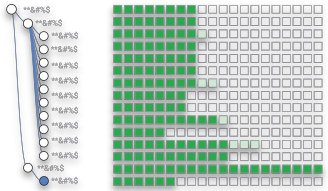

Tree views 遅いパイプラインの**ブロッカー**を特定するのに役立つ

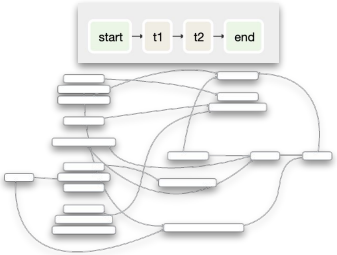

Graph views ワークフローの**依存関係**とステータスを包括的に確認可能

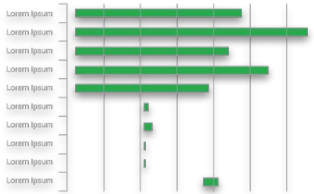

Gantt views タスクの継続時間を分析してボトルネックを特定可能

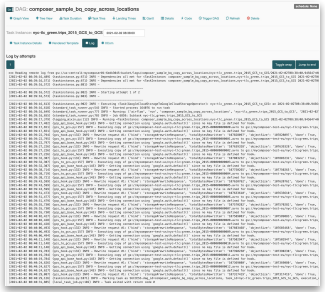

ログを参照可能

Workflows

- サーバレス
- 迅速なスケーラビリティ
- 複雑な処理の自動化
- 組み込みのエラー処理
- Google Cloud 利用時の組込み認証
- http ベースのサービス連携

Workflows の開発

- YAML でワークフローを定義
- Console での開発も可能
- 処理の流れを可視化

```
# 各処理をステップと呼ぶ
# getMessage と returnValue がステップ
- getMessage:
    call: http.post
    args:
      url: https://www.example.com/endpoint
      body:
        someVal: "Hello World"
        anotherVal: 123
    result: theMessage
- returnValue:
    return: ${theMessage.body}
```

Workflows の依存関係の定義

- 基本的には書いた順序に実行される
- 複雑な処理も定義可能
  - 制御文で条件分岐
  - サブワークフローを定義し実行

```
- getCurrentTime:
    call: http.get
    args:
      url: https://us-central1-workflowsample.cloudfunctions.net/datetime
    result: currentTime
- conditionalSwitch:
    switch:
      - condition: ${currentTime.body.dayOfTheWeek == "Friday"}
        next: friday
      - condition: ${currentTime.body.dayOfTheWeek == "Saturday" OR
currentTime.body.dayOfTheWeek == "Sunday"}
        next: weekend
    next: workWeek
- friday:
    return: "It's Friday! Almost the weekend!"
- weekend:
    return: "It's the weekend!"
- workWeek:
    return: "It's the work week."
```

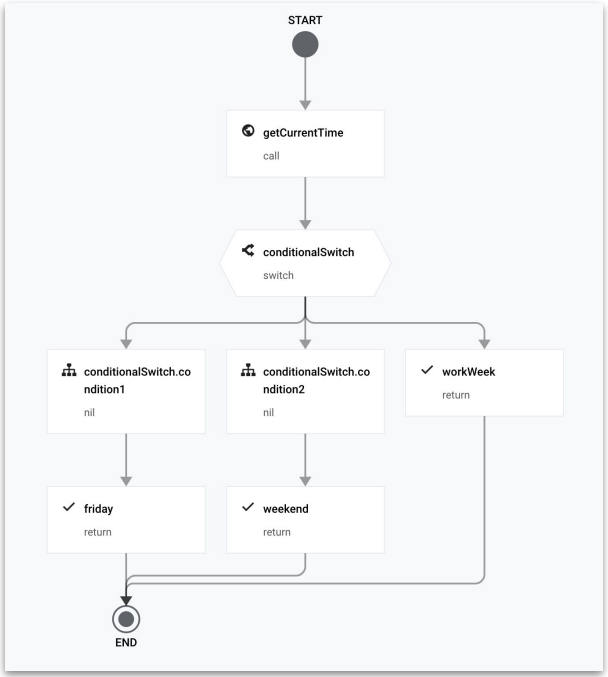

Workflows のスケジュール機能

- Workflows 自体にスケジュール機能はなく cloud scheduler で設定する
- cron 形式で定義


```
gcloud scheduler jobs create http JOB_NAME \
  --schedule="*/5 * * * *" \
--uri="https://workflowexecutions.googleapis.com/v1/projects/PROJECT_NAME/locations/REGION_
NAME/workflows/WORKFLOW_NAME/executions" \
  --time-zone="TIME_ZONE" \
--oauth-service-account-email="SERVICE_ACCOUNT_NAME@PROJECT_NAME.iam.gserviceaccount.com"
```

Workflows が連携可能なサービス

- http ベースの API サービス
- Google Cloud API（Pub/Sub、Firestore 等）

```
- STEP_NAME:
    call: {http.get|http.post|http.request}
    args:
        url: URL_VALUE
        [method: REQUEST_METHOD]
        [headers:
            KEY:VALUE
            ...]
        [body:
            KEY:VALUE
            ...]
        [query:
            KEY:VALUE
            ...]
        [auth:
            type:{OIDC|OAuth2}]
        [timeout: VALUE_IN_SECONDS]
    [result: RESPONSE_VALUE]
```

```
- callMyFunction:
   call: http.post
   args:
     url:
https://us-central1-myproject123.cloudfunctions.net/myfunc1
     auth:
       type: OIDC
     body:
       someVal: "Hello World"
       anotherVal: 123
   result: theMessage
- returnValue:
   return: ${theMessage.body}
```

Workflows エラー処理

- 組込みの通知はないので例外ハンドリングやカスタムのロギングで
- 実行中のステップに対するリトライは可能
- ステップの例外ハンドリングも可能
- 失敗したワークフローの再実行
  - 再実行というよりは新規に実行
  - 途中のステップからの実行は不可


```
- step_name:
    try:
        steps:
            ...
    retry:
        predicate: ${http.default_retry_predicate_non_idempotent}
        max_retries: 10
        backoff:
            initial_delay: 1
            max_delay: 90
            multiplier: 3
```

```
- read_item:
    try:
        call: http.get
        args:
            url: https://host.com/api
        result: api_response
    except:
        as: e
        steps:
            - known_errors:
                switch:
                - condition: ${not("HttpError" in e.tags)}
                  return: "Connection problem."
                - condition: ${e.code == 404}
                  return: "Sorry, URL wasn't found."
                - condition: ${e.code == 403}
                  return: "Authentication error."
            - unhandled_exception:
                raise: ${e}
- url_found:
    return: ${api_response.body}
```

Workflows の監視

- デフォルトでは実行状態はロギングされない
- Cloud logging との連携で監視
  - カスタム ロギングで実行状況を出力して監視

```
- step1:
    assign:
        - varA: "Hello"
        - varB: "World"
- logStep:
    call: sys.log
    args:
        text: TEXT
        severity: SEVERITY
- step2:
    return: ${varA + " " + varB}
```

Dataform

- DWH 内でデータパイプラインを構築する ELT の T（変換）に特化
- SQL が書ける Analyst がセルフサービスでデータの準備が可能
- DWH の処理能力、拡張性、可用性などのメリットを享受
- バージョン管理、テスト、コラボレーションの仕組み

stg_customer.sqlx

```
config {
  type: "table"
}

select r_name,
       n_name,
       cust.*
from
${ref("stg_nation")} as nation , ${ref("customer")} as cust
where n_nationkey = c_nationkey
```

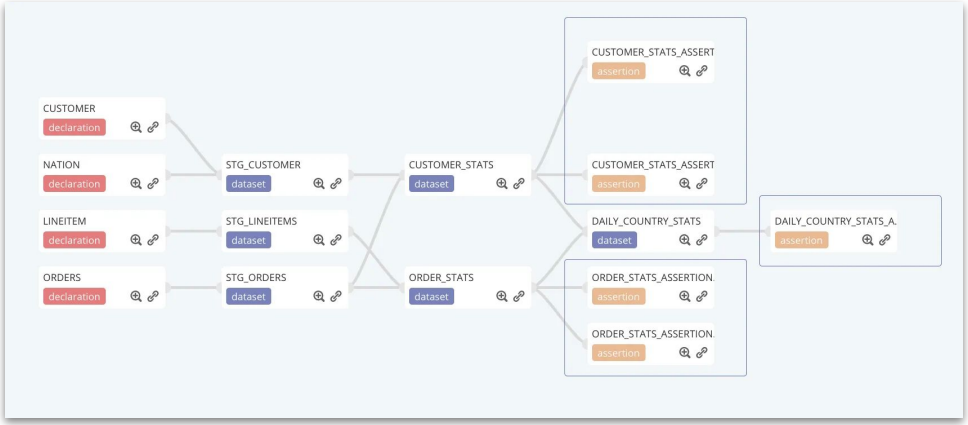

Dataform で利用可能なデータウェアハウス

- 外部サービスとの連携は不可
- ワークフローを定義、実行可能な対応データ ウェアハウス
  - BigQuery
  - Amazon Redshift
  - Snowflake
  - Azure SQL Data Warehouse
  - PostgreSQL

Supported warehouses

Dataform の開発方法

- SQLX という SQL の拡張言語で開発
  - データ変換処理部分は、基本的に SQL による記述
  - 拡張部分 : メタデータ、依存テーブルの指定などのビルトイン関数、JavaScript による動的な SQL の生成

```
config {
  type: "table",
  description: "combine natio table and region table",
  columns: {
    r_name: "region name",
    n_name: "country name",
    n_nationkey: "country id"
  }
}

select r_name,
       n_name,
       n_nationkey
from
${ref("nation")} , ${ref("region")}
where r_regionkey = n_regionkey
```

Dataform 依存関係の定義

- ビルトイン関数 ${ref("参照先")} で定義

```
config {
  type: "table",
  description: "customer table joined with customer and
stg_nation",
  columns: {
    r_name: "region name",
    n_name: "nation name",
    cust: "all customer columns"
  }
}

select r_name,
       n_name,
       cust.*
from
${ref("stg_nation")} as nation , ${ref("customer")} as cust
where n_nationkey = c_nationkey
```

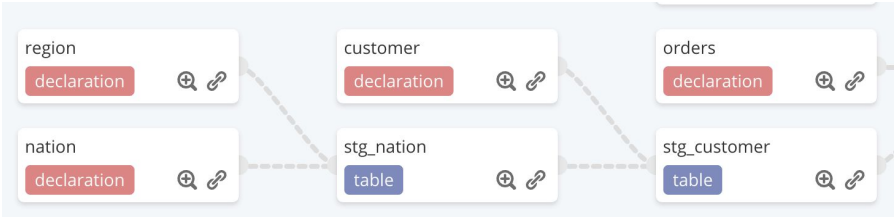

Dataform スケジュール定義

- cron ベース
  - cron 定義でも GUI でも定義可能
  - タイムゾーン は UTC のみ

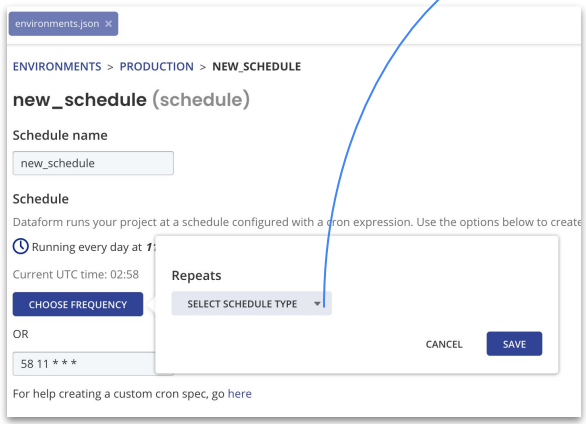

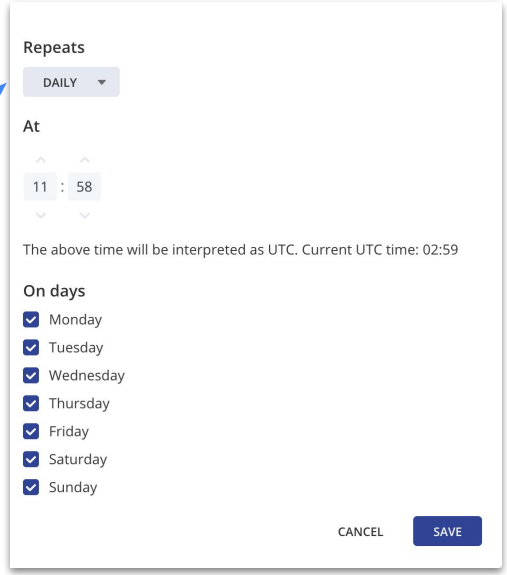

定義は json ファイルに追加される

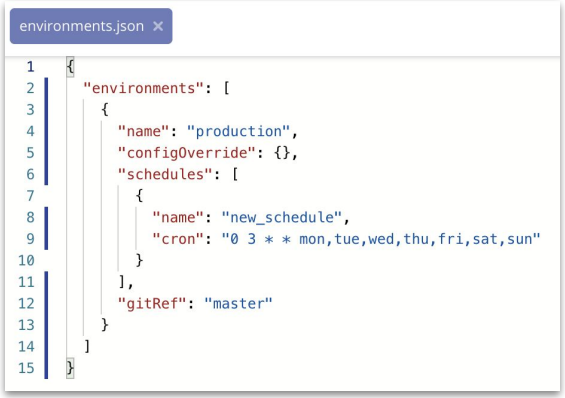

Dataform エラー処理

- 通知
  - email or slack が選べる
  - schedule に対しての紐付け
  - 成功時にも通知可

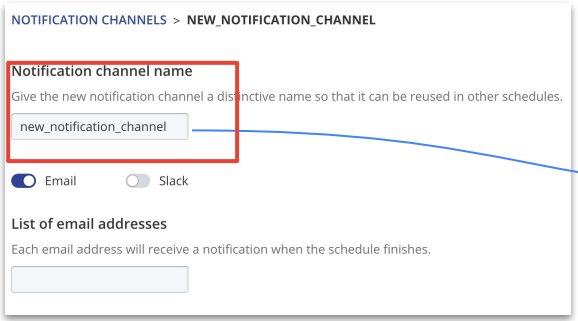

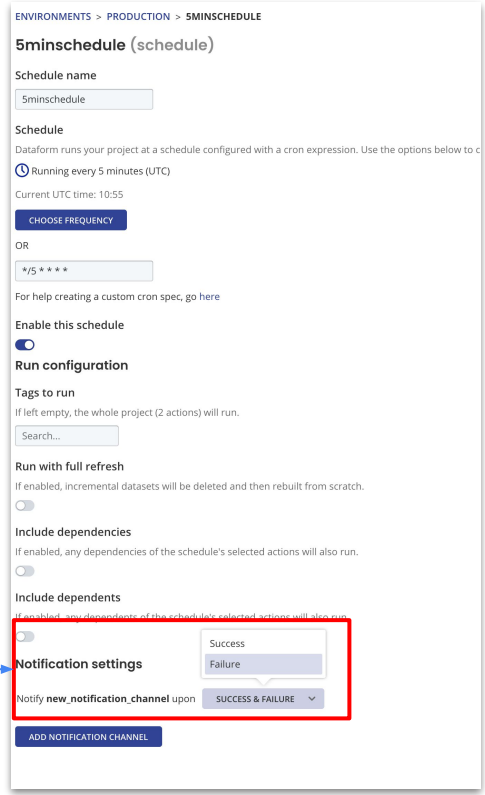

Dataform エラー処理

- 実行中のアクション（各 SQL の処理）のリトライはなし
- 失敗したワークフローの再実行
  - 再実行というよりは新規に実行
  - 途中からの実行は可能
    - アクションやタグ単位での実行ができる
    - 依存関係のある処理もあわせて実行できる

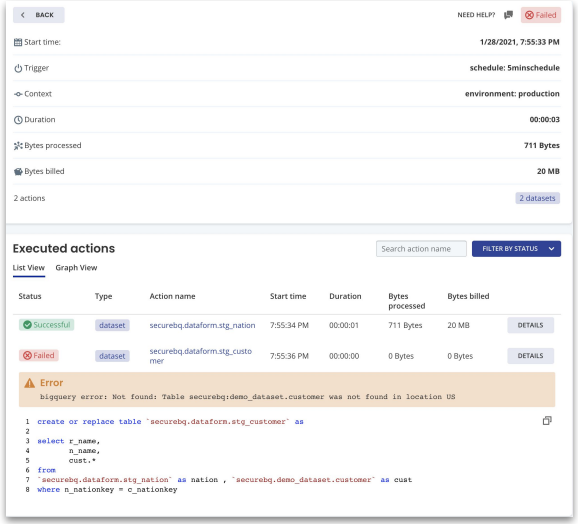

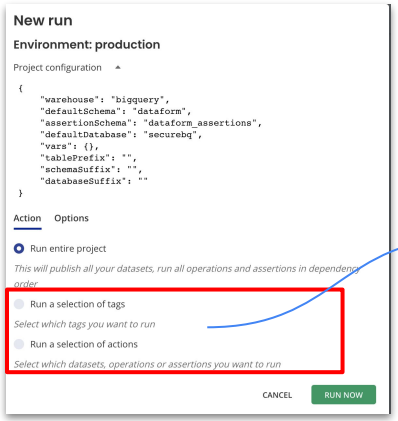

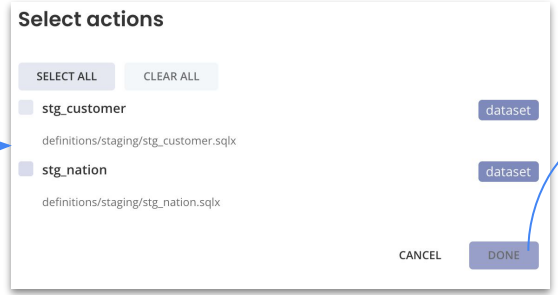

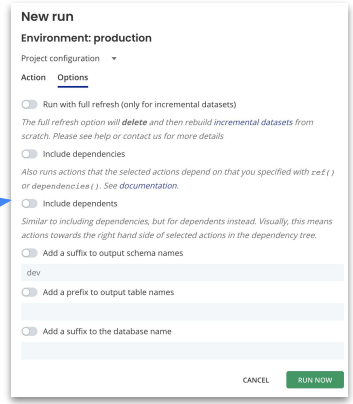

Dataform の監視

- Dataform UI のログから実行状態を監視することが可能

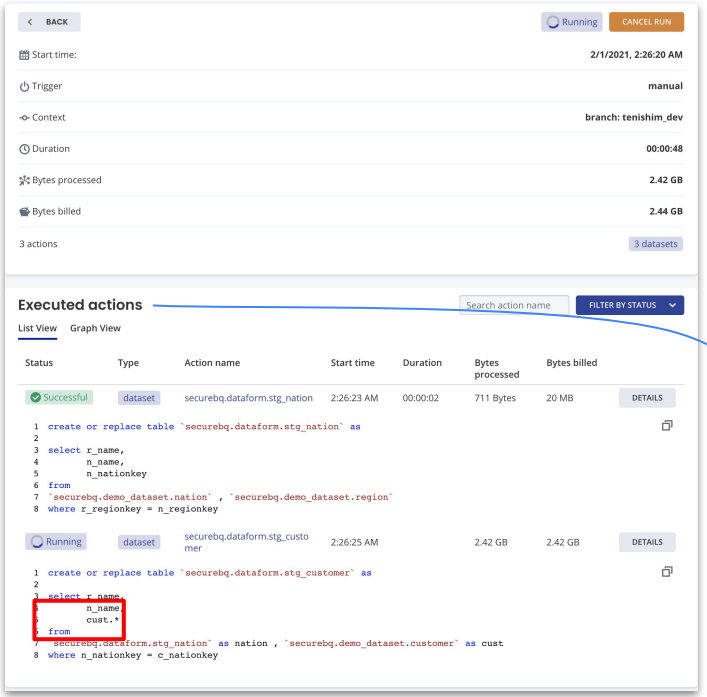

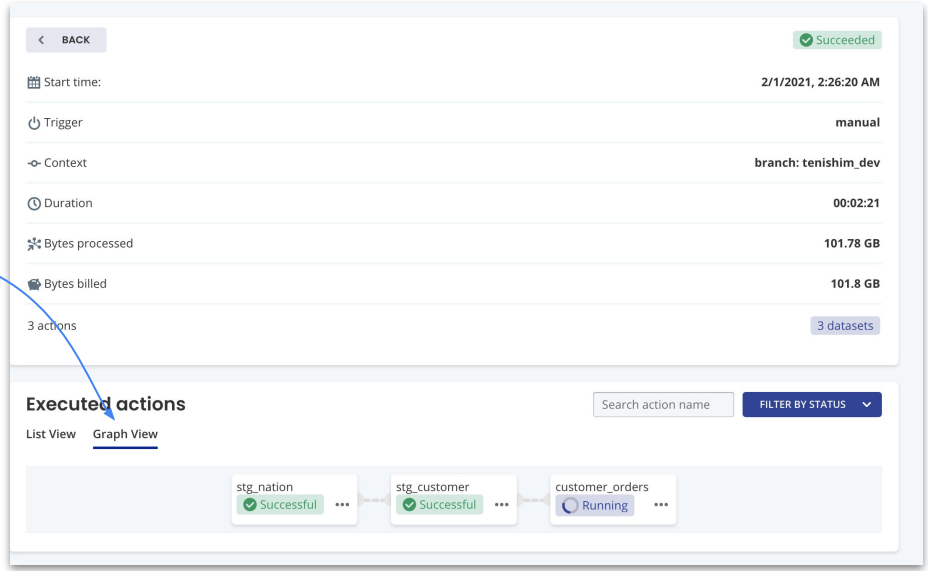

Cloud Data Fusion

- フルマネージドのデータ統合サービス
- OSS の CDAP がベース
- GUI 操作でデータの収集、処理、整形、加工を実施可能
- ストリーミングとバッチ対応
- Google Cloud 含め多くのサービスとの連携が可能
- パイプラインは Dataproc で実行

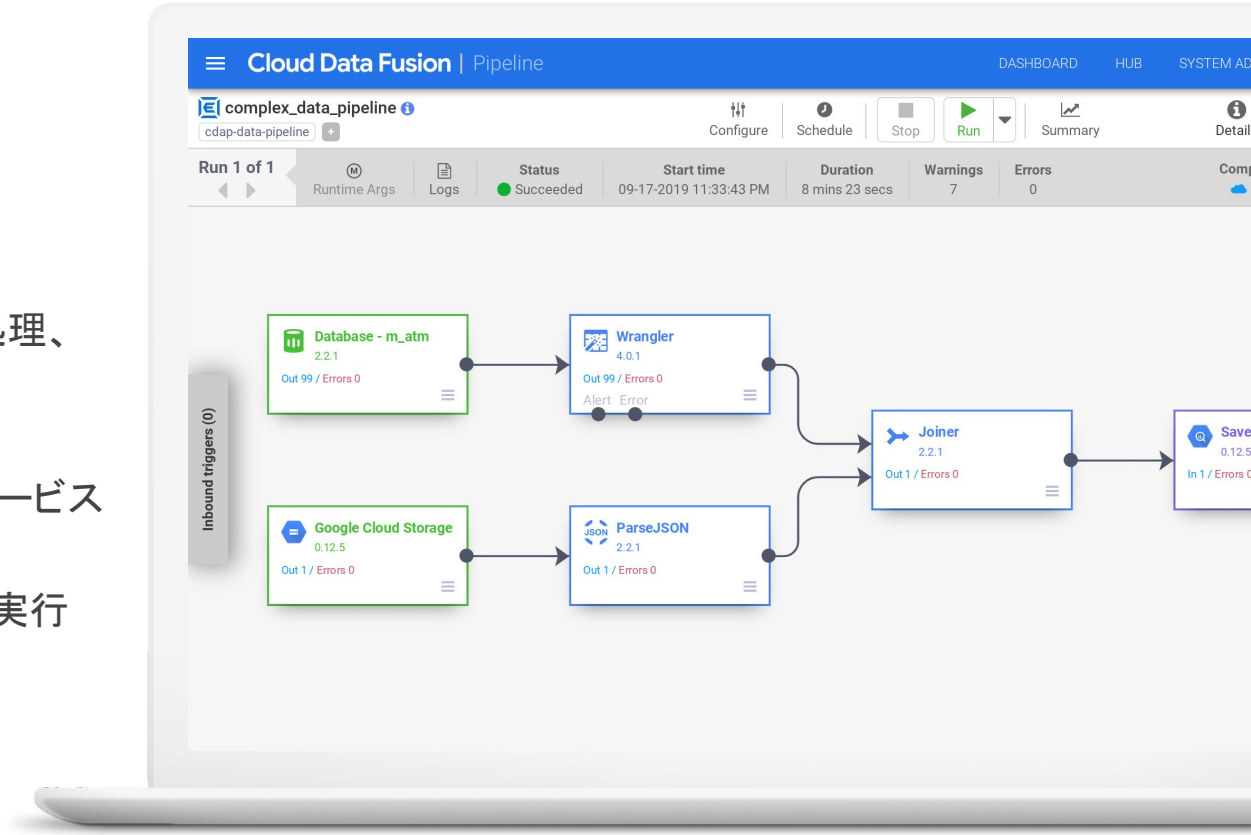

Cloud Data Fusion の開発

- GUI で開発
  - データソース、変換、シンク等のプラグインをつなげてパイプラインを構築
  - コーディング可能なプラグインもある
- Preview モードでパイプラインのデバッグが容易

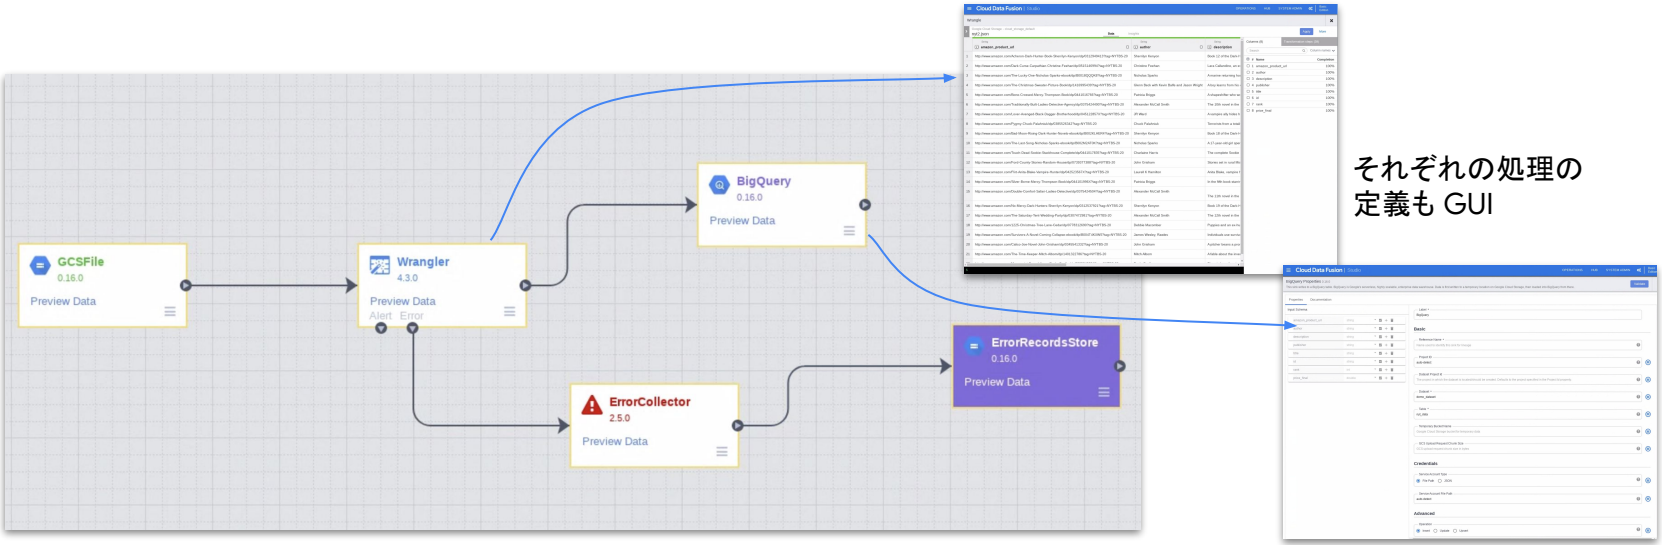

それぞれの処理の
定義も GUI

Cloud Data Fusion 依存関係の定義

- 変換処理（ノード）の依存関係は矢印でつないで定義
- データの中身に応じて変換内容を変えるなどの分岐も可能
- パイプラインをつなげて順次実行も定義可能

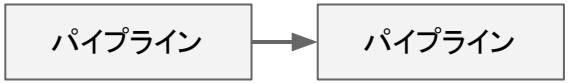

パイプライン

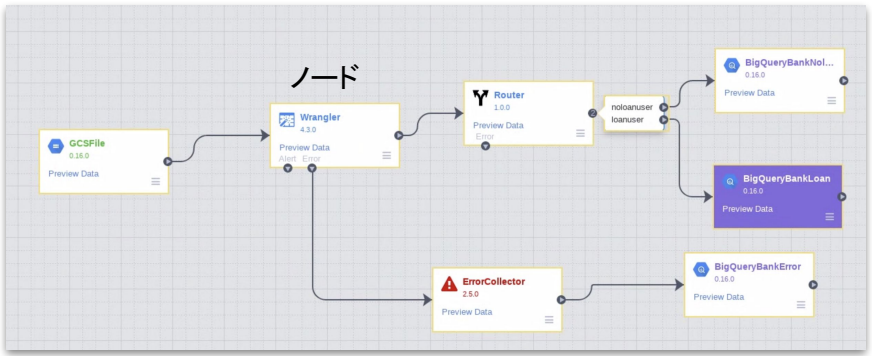

パイプラインをトリガーにして、次のパイプラインを実行

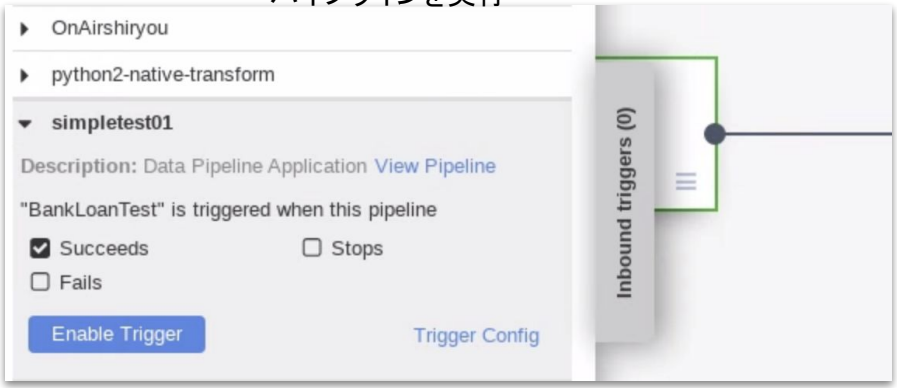

Cloud Data Fusion の連携可能なサービス プラグイン

- データソース、データシンク、アクション プラグインで多くの外部サービスと連携
- その他、汎用的な変換、分析、エラー処理用など様々なプラグインを提供

データソース		データシンク		アクション（コマンドを実行）	
Oracle SQL Server IBM DB2 MySQL PostgreSQL Redshift Teradata Netezza Snowflake BigQuery	Database（JDBC） GCS S3 Azure Blob Store Salesforce ServiceNow Elasticsearch Splunk Cloud Spanner その他	Oracle SQL Server IBM DB2 MySQL PostgreSQL Redshift Teradata Netezza Snowflake BigQuery	Database（JDBC） GCS S3 Salesforce Send Grid Elasticsearch Splunk Cloud Spanner その他	Oracle Execute IBM DB2 Execute SQL Server Execute MySQL Execute PostgreSQL Execute Redshift to S3 S3 to Redshift Teradata Execute	Netezza Execute Snowflake Run SQL Snowflake to Cloud Storage Cloud Storage to Snowflake Database（JDBC） S3 Client その他

Cloud Data Fusion スケジュール機能

- cron ベース
  - cron 形式でも GUI 定義でも可能
- パイプラインの同時実行も制御可能

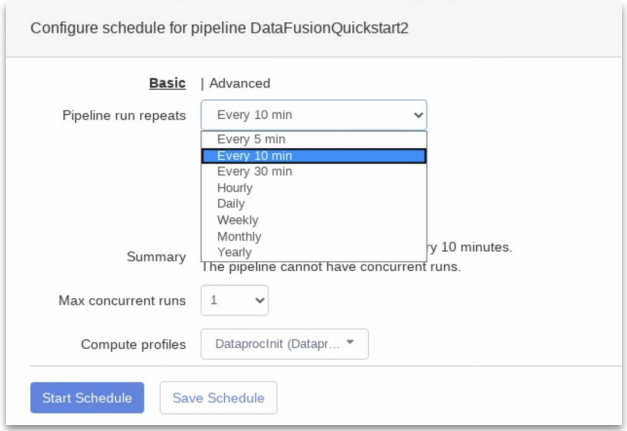

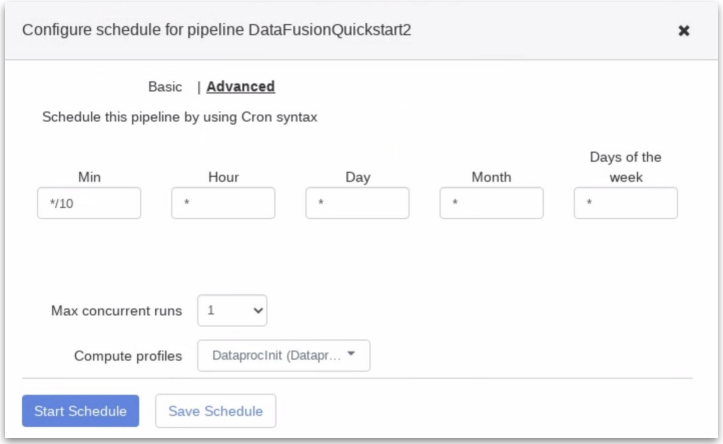

Cloud DataFusion エラー処理

- 通知処理
  - Email や HTTP call などのアラートがパイプラインの completion, failure, success の状態から選択可能
  - JDBC でデータベースにつないでクエリの実行も可能

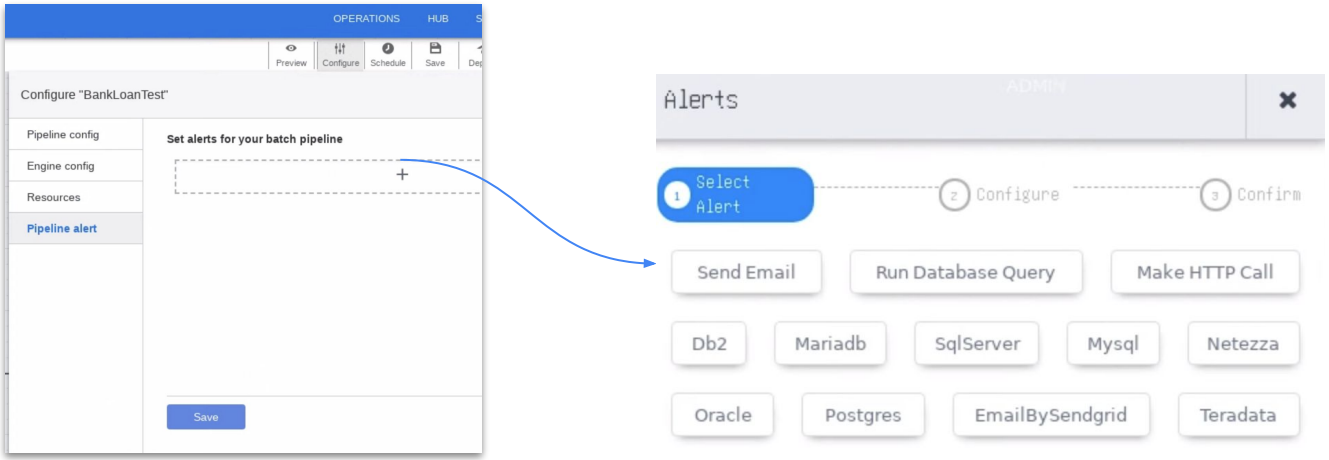

Cloud Data Fusion エラー処理

- 実行中のノードのリトライは可能
  - Spark や MapReduce の設定を利用可能
  - Data fusionから設定を上書きすることが可能
- 失敗したパイプラインの再実行
  - 再実行というよりは新規での実行
  - 途中のノードからの実行は不可

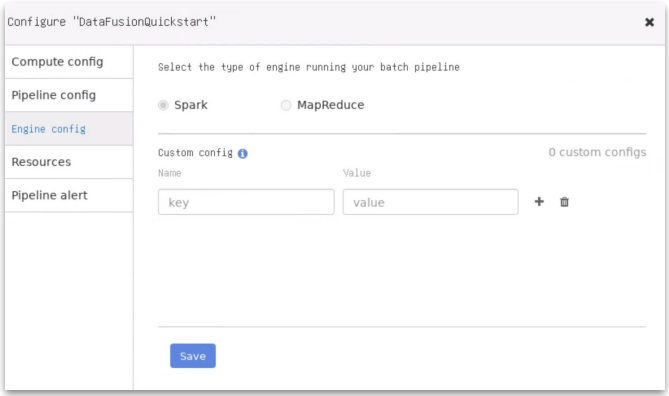

Cloud Data Fusion の監視

- 実行中のデータの処理状況を確認可能
  - Input / Output 件数
- ログもリアルタイムで監視可能

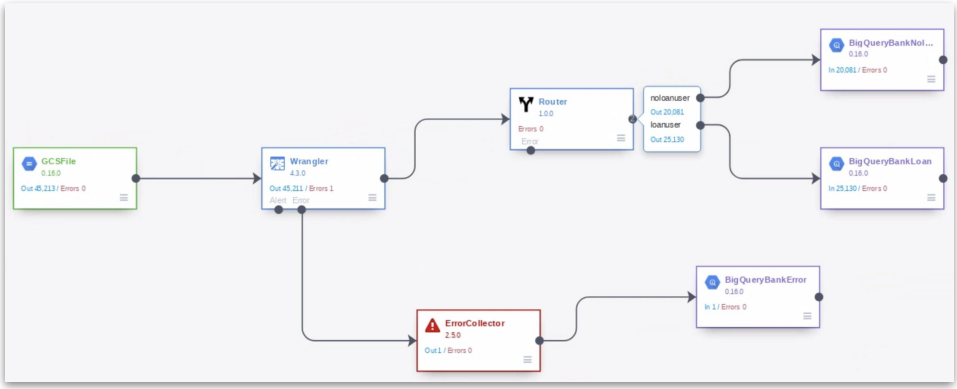

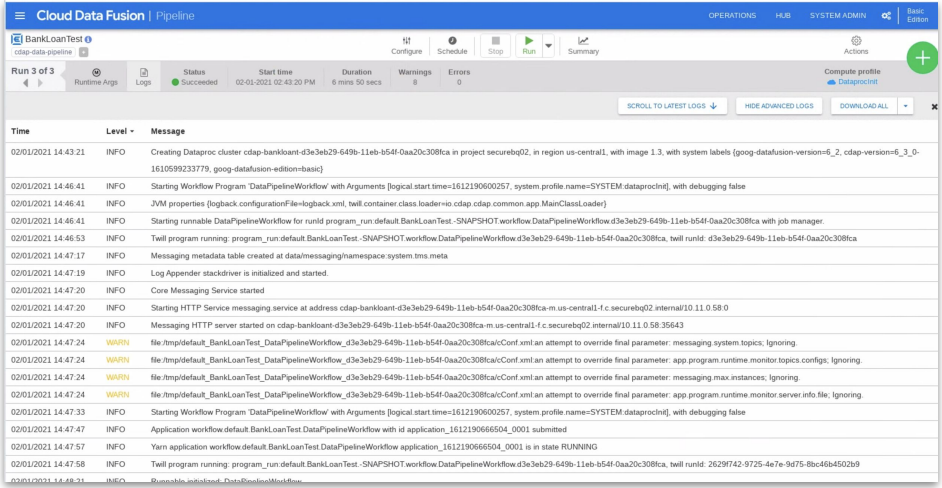

まとめ

	Cloud Composer	Workflows	Cloud Data Fusion	Dataform
ユースケース	**複数のデータ処理サービスを束ねるワークフロー エンジンとしての利用 複雑なワークフローやエラー ハンドリングなど**	**API ベースのサービスを束ねるワークフローエンジンとしての利用。複雑な処理の自動化**	**データ統合のための変換処理としての利用がメイン**	**DWH 内での依存関係をもった変換処理をバッチとして実行**
運用・管理	フルマネージド	サーバレス	フルマネージド	サーバレス
依存関係の定義	タスクの順次実行だけでなく分岐など柔軟な定義が可能	タスク（ステップ）の順次実行だけでなく分岐など柔軟な定義が可能	変換処理（パイプライン ノード）の流れの依存関係定義がメイン。	変換処理（アクション）の順次実行定義が可能
スケジュール機能	実行間隔だけでなく開始日、終了日などの定義でより柔軟なスケジューリングが可能	Cloud Scheduler（フルマネージドのcronサービス）で定義	cron ベースでの定義 （GUI で定義可能）	cron ベースでの定義 （GUI で定義可能）
開発言語	Python でワークフローの定義	YAML でワークフローの定義	GUI でパイプラインの定義 ビルトインの変換処理も多数提供されている	主に SQL で JavaScript やビルトイン関数などを合わせてパイプラインの定義
連携可能なサービス	様々な種類のサービスと連携できるようになっている。（Operatorとして提供） カスタム Operator を作成可能	googleapi と http	多数のサービスとの連携が可能。（プラグインとして提供）カスタムプラグインの作成も可能	特定の DWH 内での処理のみ
エラー処理	タスクのリトライの柔軟な設定が可能。 失敗したワークフローの再実行、途中のタスクからの実行など柔軟な再実行が可能	ステップのリトライの柔軟な設定が可能。失敗したワークフローの再実行というよりは新たに実行しなおす。	変換処理のリトライはビルトインの種類による。失敗したパイプラインは、再実行というよりは新たに実行しなおす。	リトライ処理はなし。失敗したパイプラインは再実行というよりは新たに実行しなおす。パイプラインの途中からの実行は可能
エラー通知	email 通知やエラー時の callback の定義で通知可能	単体ではエラー通知の機能はない	email 、http コールでの通知	email 、slack での通知
監視	様々な角度から監視できるように多数の UI を提供	実行状態の監視は明示的にログ出力が必要	実行状態をログで監視可能 変換の input output の件数も監視可能	UI のログから実行状態を監視可能

Thank you